

控制与决策

Control and Decision

考虑退化轨迹差异性与相似性的轴承RUL预测

刘小峰, 冯伟, 柏林

引用本文:

刘小峰, 冯伟, 柏林. 考虑退化轨迹差异性与相似性的轴承RUL预测[J]. 控制与决策, 2021, 36(11): 2832–2840.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1028>

您可能感兴趣的其他文章

Articles you may be interested in

[基于动态蚁群劳动分工模型的多AUV任务分配方法](#)

A multi-AUV dynamic task allocation method based on antcolony labor division model

控制与决策. 2021, 36(8): 1911–1919 <https://doi.org/10.13195/j.kzyjc.2019.1312>

[基于深度时序特征迁移的轴承剩余寿命预测方法](#)

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

[基于批次图像化的卷积自编码故障监测方法](#)

Fault detection of batch image-based convolutional autoencoder

控制与决策. 2021, 36(6): 1361–1367 <https://doi.org/10.13195/j.kzyjc.2019.1342>

[区分交通流模式的混合服务路口信号控制策略](#)

Signal control strategies of mixed service intersections to discriminate traffic flow patterns

控制与决策. 2021, 36(6): 1509–1515 <https://doi.org/10.13195/j.kzyjc.2019.1520>

[改进集成深层自编码器在轴承故障诊断中的应用](#)

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

考虑退化轨迹差异性与相似性的轴承RUL预测

刘小峰[†], 冯伟, 柏林

(重庆大学 机械与运载工程学院, 重庆 400044)

摘要: 轴承的个体异质性及工况差异性使得其性能退化轨迹不尽相同, 导致训练轴承建立的深度学习模型与测试轴承失配。对此, 提出基于卷积自编码器与自组织映射的轴承剩余使用寿命(remaining useful life, RUL)灰色预测方法。该方法引入以轴承自身监测数据为驱动的批量归一化的卷积自编码器对轴承性能退化特征进行深度提取, 并结合自组织映射算法进行性能退化指标(degradation indicator, DI)自主构建。采用动态时间规划算法对各个轴承退化轨迹进行相似匹配分析, 以相匹配的全寿命轴承的DI灰色模型回归曲线在寿命终点取值作为参考, 进行测试轴承的失效阈值设置。以测试轴承历史DI为驱动, 采用全阶时间幂灰色预测模型对测试轴承RUL进行滚动预测。实验结果表明, 所提出方法在保留轴承退化趋势个体差异性的同时, 能够实现轴承失效阈值自主合理设置, 提高轴承RUL的预测精度。

关键词: 寿命预测; 卷积自编码器; 自组织映射; 动态时间规划; 退化轨迹; 全阶时间幂灰色预测

中图分类号: TH17; TH133.3; TP18

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1028

开放科学(资源服务)标识码(OSID):

引用格式: 刘小峰, 冯伟, 柏林. 考虑退化轨迹差异性与相似性的轴承RUL预测[J]. 控制与决策, 2021, 36(11): 2833-2840.



Prediction of bearing remaining useful life involving difference and similarity of degradation trajectories

LIU Xiao-feng[†], FENG Wei, BO Lin

(College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044, China)

Abstract: The individual heterogeneity and working condition difference of bearings lead to the different performance degradation tracks of bearings, which results in the mismatch between the deep learning model established by full-life bearing and the test bearing. Aiming to this problem, this paper proposes a remaining useful life(RUL) grey prediction method based on convolutional autoencoders(CAEs) and self-organizing maps(SOMs). In this method, a batch normalized CAE driven is introduced to extract the deep features of bearing performance degradation, and the self-organizing maps algorithm is used to construct the performance degradation indicator(DI). The algorithm of dynamic time warping(DTW) is applied to match the bearing degradation trajectories, and the DI curve of the bearing with similar degradation trajectory is used as the reference to set the failure threshold of the test bearing. Driven by the history DIs of the test bearing, the gray forecasting model with full order time power terms(FOTP-GM) is used to predict the RUL of the test bearings. The experimental results show that the proposed method not only retains the individual differences of bearing degradation trend, but also realizes the independent and reasonable setting of bearing failure threshold and improves the prediction accuracy of RUL.

Keywords: RUL Prediction; convolutional auto-encoder; self-organizing maps; dynamic time warping; degradation trajectory; gray forecasting model with full order time power terms

0 引言

通过对轴承的工作状态进行有效监测, 及时准确地预测其剩余寿命(RUL), 对保障机械设备安全可靠运行、延长设备工作周期、避免巨大经济损失具有重要意义。基于数据驱动的轴承RUL预测方法无需了解系统复杂的退化机理, 降低了对前期经验数据储备

的依赖性, 具有预测准确性高、适用性强、操作方便等优点。基于数据驱动的轴承RUL预测方法的关键在于提取有效的能表征其性能衰退的退化指数(DI)、失效阈值的设置以及预测模型的建立。传统的轴承RUL预测方法, 通常是从原始监测信号中提取时域或频域单一的统计特征作为健康指标, 包括相对方根

收稿日期: 2020-07-25; 修回日期: 2020-09-27.

基金项目: 国家自然科学基金项目(51975067); 国家重点研发计划项目(2018YFB2001400).

责任编辑: 关治洪.

[†]通讯作者. E-mail: liuxfeng0080@126.com.

均值^[1]、能量熵^[2]等,但这种单一特征的表征能力存在很大的局限性。为了提高特征对轴承性能退化的表征能力,学者们采用PCA^[3]、KPCA^[4]等特征降维方法构建融合DI。这些基于特征降维的DI构建方法在降维过程中往往损失部分有用信息,难以保证融合特征与RUL的相关性。

基于深度学习的轴承性能退化特征提取与RUL预测方法得到了长足的发展,主要包括:深度置信网络^[5]、基于时域和频域特征的集成深度学习方法^[6]、卷积神经网络(CNN)^[7-8]、自编码器^[9]、循环神经网络^[10]、长短时记忆网络编码和解码器^[11]等。需要指出的是,这些方法通常是在假定训练轴承与测试轴承退化轨迹相同或相似的前提下,采用训练轴承的全寿命数据训练的深度学习模型建立测试轴承监测数据与其RUL之间的非线性映射关系。而在实际工程应用中,由于轴承个体的差异性与环境工况的影响,同工况下的轴承不一定具有相似的退化轨迹,而不同工况环境下的轴承也有可能具有相似的退化趋势。另外,基于深度学习的预测模型需要以足量的历史数据为前提条件,而测试轴承的数据大多是在其正常运行状态获得的,故障状态下的数据较少,这种情况下,传统的以测试轴承自身监测数据为驱动的RUL深度模型预测方法难以达到理想效果。

针对观测数据不足的问题,文献[12-13]引入了迁移学习方法将退化数据从训练轴承迁移到目标测试轴承,在迁移数据的基础上建立深度学习模型。值得注意的是,由于轴承的个体异质性,领域适配后数

据与RUL的非线性关系不一定适合目标测试轴承。在现有基于数据驱动的轴承RUL预测的研究文献中失效阈值的设置主要采用人工经验法^[14]、20 g的振动加速度阈值^[15]及寿命百分比统一阈值^[16]3种设置方法。这些失效阈值设置方法存在较大的人为主观性,没有考虑轴承性能退化过程的差异性,其工程实用性非常有限。

针对以上存在的问题与挑战,本文在兼顾轴承退化轨迹差异性与相似性的情况下,提出了基于个体轴承监测数据为自驱动的DI构建方法和基于退化轨迹相似匹配的失效阈值设置方法,并在此基础上对轴承RUL进行灰色预测。所提出方法如图1所示。该方法以振动信号频谱作为卷积自编码器(convolutional autoencoder, CAE)的输入,结合批量归一化,完成退化特征的深度提取,并将提取出的特征经过自组织映射(self-organizing maps, SOM)得到轴承的DI,避免了传统DI构建算法中复杂特征提取筛选及融合过程。引入动态时间规划(dynamic time warping, DTW)算法对轴承性能退化轨迹进行相似性匹配分析。采用全阶时间幂灰色预测模型(gray forecasting model with full order time power terms, FOTP-GM)对全寿命训练轴承的失效阈值进行灰色拟合。参考与测试轴承退化轨迹最匹配的训练轴承的失效阈值,对测试轴承的DI阈值进行了设置。最后采用FOTP-GM(1,1)模型对测试轴承RUL进行预测。

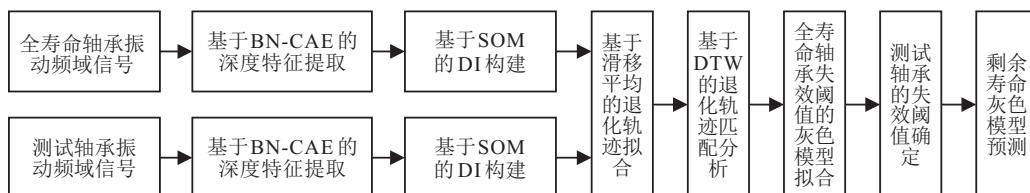


图1 方法流程

1 性能退化轨迹构建

1.1 基于CAE的性能退化特征提取

鉴于轴承退化趋势的个体差异性,采用卷积自编码器对轴承的自身历史监测数据进行无监督学习,实现轴承性能退化特征的自主提取。CAE是一种无监督学习方法,无需轴承RUL先验知识便可以自动提取轴承监测数据中退化状态特征。CAE的核心部分也是编码和解码两部分,与自编码器(AE)不同的是,CAE的编码部分采用卷积操作,解码部分采用反卷积操作,在训练参数与特征提取方面均比AE有显著提高^[17]。CAE编码器的卷积网络学习将输入信号编码为一组隐藏空间表示,然后解码器重构输入信

号。为了加快训练速度,并增加网络的泛化能力,在编码部分对卷积结果和解码部分反卷积结果均进行批量归一化操作,使每一层拥有服从相同分布的输入数据,从而可以使用较大的学习率进行训练,加快训练速度,克服协方差偏移的影响。对于*i*时刻的轴承时域信号 X_i ,其潜在的压缩特征为

$$h^k(F_i) = \sigma(F_i \otimes W^k + b^k). \quad (1)$$

其中: $\sigma(\cdot)$ 为激活函数, W^k 和 b^k 分别为卷积核的权重和偏差。将得到的 h^k 进行特征重构,可以得到重构的频谱为

$$\hat{F}_i = \sigma(h^k \otimes \hat{W}^k + c^k), \quad (2)$$

其中 \hat{W}^k 、 c^k 分别为解码器的卷积核权值和偏差。将输入的频谱 F_i 与最终重构得到的频谱 \hat{F}_i 进行欧几里得距离比较,通过反向传播算法进行优化,完成CAE的训练,即

$$E = \sum \|F_i - \hat{F}_i\|^2. \quad (3)$$

最小化损失函数 E 即可得到一个最佳的隐层特征空间表示,将其作为该时刻轴承性能退化的特征。CAE提取的深度特征属于物理特征,无法充分体现轴承在衰退过程中的时序特性,因此这些深度特征对轴承性能趋势性退化并不敏感,有必要将这些深度特征融合成统一的DI。

1.2 DI构建

基于SOM的轴承DI建立,是通过正常状态下的轴承深度特征进行训练获得输出神经元的权值矢量,此时竞争网络的权值向量能够代表输入向量的特征。计算轴承性能衰退期提取的深度特征与所有权值向量的最小欧氏距离,该距离则是具有物理意义的轴承性能衰退指数。设置 X_i 为测试轴承通过其CAE模型获得的深度特征向量,记为 $X_i = (h_i^1, h_i^2, \dots, h_i^k)$ 。 W_j 为权值向量, $W_j = (w_j^1, w_j^2, \dots, w_j^k)$, $i = 1, 2, \dots, N$, N 为训练样本数, $j = 1, 2, \dots, m$, m 为拓扑神经元数量, k 为提取的深度特征维度。训练过程先将 X_1 作为SOM的输入,通过欧氏距离最小的标准: $\|X_1 - W_c\| = \min \|X_1 - W_j\|$,选取获胜神经元 c ,根据文献[18]对权值向量、学习率及邻域半径进行更新。然后将 N 个训练样本点依次按照相同的步骤输入SOM,所有的训练样本都参与完SOM的训练代表一次迭代结束;当迭代次数达到设定阈值时,可得到正常特征样本建立的SOM模型。对于性能衰退阶段获得的深度特征向量 X_1 ,将其到权值矢量的欧氏距离的最小值作为对应的 t 时刻的DI值,即

$$\text{DI}(t) = \min\{\|X_t - W_1\|, \dots, \|X_t - W_m\|\}. \quad (4)$$

为了消除不确定干扰因素对轴承性能退化趋势分析的影响,采用窗长为 L 的滑动窗对每个窗内的 $\text{DI}(t)$ 数据进行平滑降噪,则轴承的性能退化轨迹可表示为

$$P(t) = \begin{cases} \frac{\sum_{i=0}^t \text{DI}(i)}{i+1}, & t \leq L-1, \\ \frac{\sum_{i=0}^{L-1} \text{DI}(t-i)}{L}, & t > L-1. \end{cases} \quad (5)$$

2 基于动态时间规划的退化轨迹匹配

动态时间规划可有效地对包含噪声和时间畸变的时间序列进行层次聚类,是经典的模式相异性度量技术^[19]。基于DTW的退化轨迹匹配算法,就是将

寿命时间规整和轨迹距离测度结合起来的一种非线性规整技术。它以已知的全寿命轴承的退化轨迹为参考模板,采用测试轴承的性能退化轨迹与参考模板逐一进行比较,找出与之最佳匹配的参考模板作为测试轴承退化轨迹的匹配结果。设全寿命轴承 $P_{\text{life}}(t)$ 的长度为 n ,测试轴承 $P_{\text{test}}(t)$ 的长度为 m ,构造一个 $n \times m$ 的距离矩阵 d ,矩阵元素 $d(i, j)$ 表示 $P_{\text{life}}(i)$ 与 $P_{\text{test}}(j)$ 两点的距离,目标是寻找一条最合适的通过此矩阵网格若干格点的路径,使两条曲线最后总的距离最小。该路径记为 $w = (w_1, w_2, \dots, w_K)$,且 $\max(n, m) \leq K \leq n+m$, w 表示两个序列的规整程度, $w_k = (i, j)$ 。其中 $1 \leq k \leq K$, $1 \leq i \leq n$, $1 \leq j \leq m$,路径通过的格点即为两个序列进行计算的对齐的点。为了保证 $P_{\text{life}}(t)$ 和 $P_{\text{test}}(t)$ 的每个坐标均在 w 中出现,令 $w_1 = (1, 1)$, $w_K = (n, m)$,且 $w_k = (i, j)$ 中的 i 和 j 必须单调递增。得到的规整路径需满足最短距离路径规则,即

$$\begin{aligned} D(i, j) = & \\ d(i, j) + \min[D(i-1, j), D(i, j-1), D(i-1, j-1)]. & \end{aligned} \quad (6)$$

其中: $D(i, j)$ 为两序列从 $w_1 = (1, 1)$ 到 $w_k = (i, j)$ 的累积距离,即点 $P_{\text{life}}(i)$ 与 $P_{\text{test}}(j)$ 的欧氏距离 $d(i, j)$ 与可以到达该点的最小邻近元素的累积距离之和。 $D(n, m)$ 的值即为两序列总的累积距离,也即两序列的相似度。退化轨迹相似的轴承应具有相同的失效阈值,与测试轴承退化轨迹具有最小DTW距离的全寿命轴承的失效阈值可以作为该测试轴承的参考失效阈值。

3 基于FOTP-GM(1,1)的阈值设定与RUL预测

3.1 FOTP-GM(1,1)基本原理

FOTP-GM(1,1)是灰色预测模型衍生的新模型,该模型的结构和参数能够根据被测序列的动态变化自适应地改变,以最大程度提高拟合与预测精度。FOTP-GM(1,1)模型的离散形式为

$$\frac{x^{(1)}(t)}{dt} + ax^{(1)}(t) = \sum_{i=1}^h b_i t^{h-i} h \geq 1. \quad (7)$$

其中: a 为发展系数; b_i ($i = 1, 2, \dots, h$)为灰色作用量; h 为时间幂项 $b_i t^{h-i}$ 的阶数,最大为4。首先基于原始数据序列 $X^{(0)}$ 生成1-AGO序列 $X^{(1)}$,该序列中元素 $X^{(1)}$ 通过下式计算得到:

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k = 1, 2, \dots, n. \quad (8)$$

采用最小二乘法,可以估计FOTP-GM(1,1)模型的参数序列 a 和 b_i ,根据式(7)得到时间相应序列为

$$\hat{x}^{(1)}(t) = e^{-at} \left(\sum_{i=1}^h b_i \int t^{h-i} e^{at} dt + c \right). \quad (9)$$

在此基础上得到还原值序列 $\hat{X}^{(0)}$, 即

$$\begin{aligned}\hat{x}^{(0)}(k) &= \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k \in N, \quad k \geq 2, \\ \hat{x}^{(0)}(1) &= x^{(0)}(1).\end{aligned}\quad (10)$$

FOTP-GM(1,1)模型的结构参数会随着实际序列的动态变化而自适应地调节,不仅可以精确拟合齐次指数组列,而且可以无差拟合近似非齐次指数组列.

3.2 阈值设置

由于FOTP-GM(1,1)模型具有无差拟合近似非齐次指数组列的性能,采用FOTP-GM(1,1)模型对全寿命轴承的退化轨迹进行拟合,能够有效避免退化轨迹在最终寿命时间点上的端点畸变问题,从而降低失效阈值设置偏差. 阈值设置的具体方法为:采用FOTP-GM(1,1)模型对全寿命轴承的退化轨迹 $P_{\text{life}}(t)$ 上的 n 个数据点进行拟合,这里FOTP-GM(1,1)的阶数取4,得到拟合出的时间序列为

$$\begin{aligned}\hat{x}^{(0)}(k) &= ue^{pk} + qk^2 + rk + s, \quad k \in Z, \quad k \geq 2, \\ \hat{x}^{(0)}(1) &= x^{(0)}(1).\end{aligned}\quad (11)$$

其中 u, p, q, r, s 为拟合出的模型参数. $P_{\text{life}}(t)$ 在最终寿命时间点 $k = n$ 上的取值,即为与该训练轴承具有相似退化轨迹的测试轴承的失效阈值 TH,有

$$\text{TH} = \hat{x}^{(0)}(n). \quad (12)$$

3.3 RUL预测

传统的灰色模型仅适用于拟合纯指数变化规律的时间序列,而滚动轴承的性能退化受多种复杂因素影响,如定常扰动、定速扰动和加速度扰动,其性能退化轨迹不会严格遵循纯指数变化规律^[20]. 基于FOTP-GM(1,1)的滚动轴承RUL预测方法,可根据滚动轴承的性能衰退趋势动态地优化模型结构,以获得对原始序列尽可能小的模拟误差,具有更高的预

测精度,更强的泛化能力. 具体实施方法为:对于测试轴承的历史DI曲线 $\text{DI}_{\text{test}}(m) (m = 1, 2, \dots, M)$ 的 M 个数据点采用式(7)进行建模并进行参数求解,在得到式(9)时间相应函数的基础上,采用式(10)进行 $\text{DI}_{\text{test}}(m)$ 未来若干点的DI预测. 当DI值达到TH时,认定达到全寿命. 最后利用全寿命 L_p 减去当前寿命 L_d 可求得RUL,即 $\text{RUL} = L_p - L_d$.

4 实验验证

4.1 数据描述

滚动轴承全寿命数据采用的IEEE PHM 2012挑战赛提供的滚动轴承全寿命数据,该数据由法国弗朗什-孔泰大学FEMTO研究所的PRONOSTIA实验平台获取^[21]. 实验台采集信号采样频率为25.6 kHz,数据采集卡(NIDAQCard-9174)每10 s采集一次数据,每次采集数据时长0.1 s,采集2560个数据点. 全寿命轴承为B1_1, B1_2, B2_1, B2_2, B3_1, B3_2; 测试轴承为B1_3, B1_4, B1_5, B1_6, B1_7, B2_3, B2_4, B2_5, B2_6, B2_7, B3_3. 其中轴承B1_1代表的是工况一下的第1个轴承,其他轴承标号以此类推.

4.2 模型训练与DI建立

对全寿命轴承与测试轴承,采用各自的检测数据建立各自的BN-CAE模型数据集 $D = \{\text{FFT}_t\}$,其中 $\text{FFT}_t \in R^{1280 \times 1}$ 表示时刻 t 处振动信号经快速傅里叶变换得到的频域信号.

本文CAE中的编码单元包含3个卷积层和3个池化层,第1层卷积层(C1)采用宽卷积核,参数为 64×1 ,目的是提取短时特征,第2个与第3个卷积层(C2与C3)均为 3×1 的小卷积核,目的是减少卷积核参数,有利于加深网络,同时可以抑制过拟合. 除C1的步长为8,其他卷积层及池化层的步长均为2; C1、C2、C3的通道数依次为8、16、32; 对每层卷积层结果进行BN处理,激活函数采用Sigmoid函数,池化

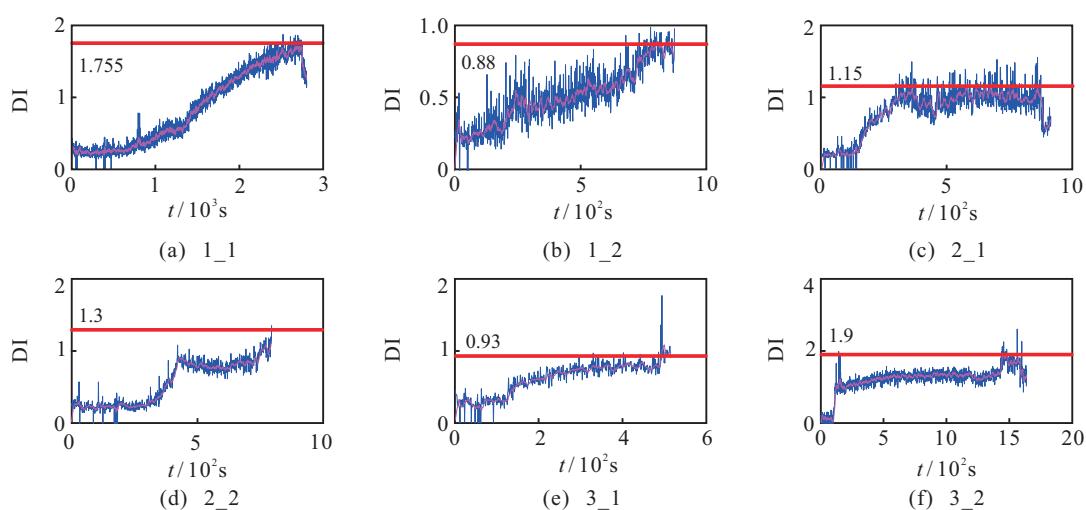


图2 全寿命轴承状态特征曲线

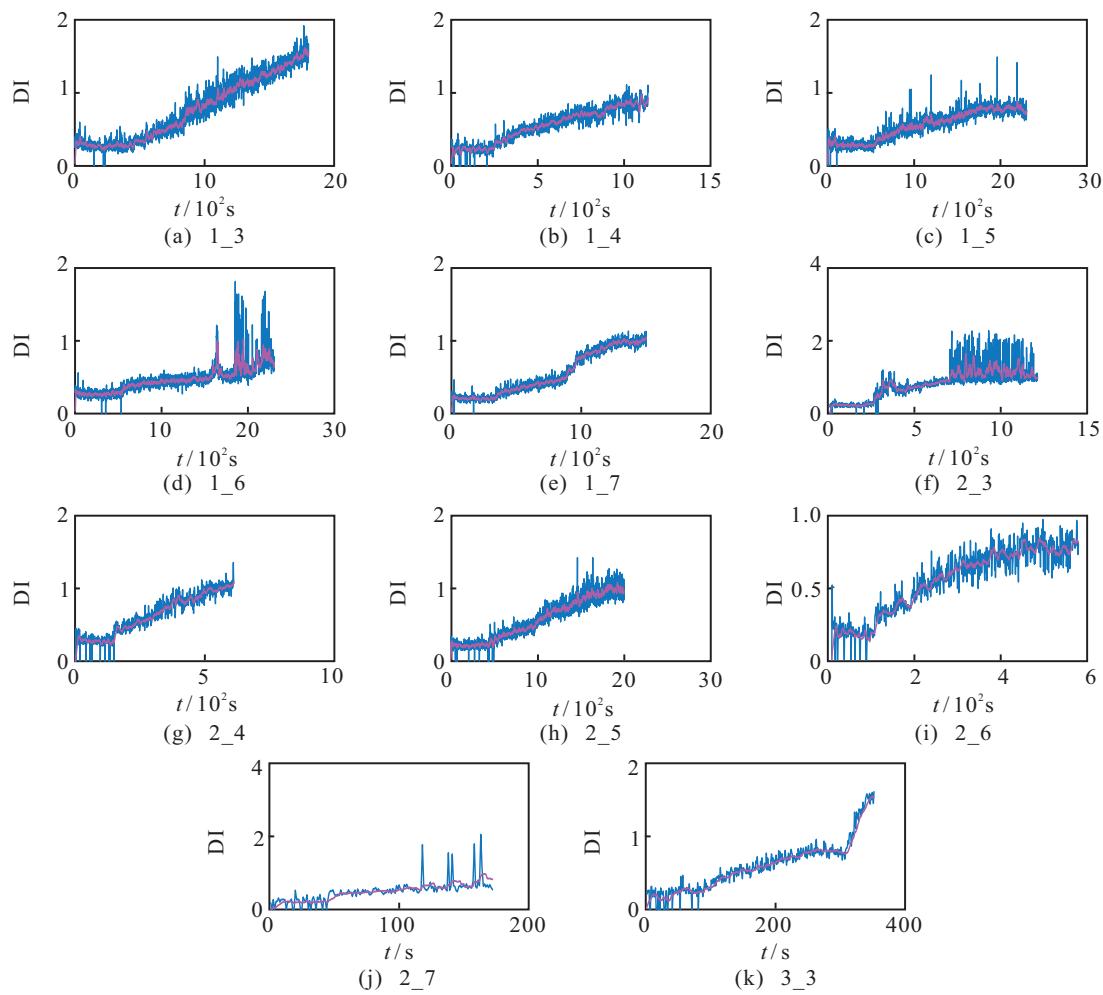


图3 测试轴承状态特征曲线

层采用最大池化,保留信号的最显著特征,卷积层和池化层均采用全0填充。卷积解码器层包括6个反卷积层,其各层参数与编码层一一对应,输出为 1280×1 尺寸特征。除最后一层,其他反卷积层结果均进行BN处理,激活函数采用Sigmoid函数,采用全0填充。

以所有轴承数据的衰退数据为基础分别建立各自的独立CAE模型,提取各自的性能退化特征,并基于各自前100个正常状态数据建立SOM模型,构建各自的DI曲线,继而根据式(5),取滑动窗长 $L = 10$,进行滑移平均后得到17个轴承的性能退化轨迹,结果如图2和图3所示。

由图2可见,同一工况下全寿命轴承的退化轨迹即使存在一定的相似性,但也表现出或多或少的差异性,其最终失效时间点所对应的DI值也并不相同。由图3可见,各个测试轴承的退化轨迹都存在明显异质性,且数据长度不一。比较图2与图3可知,由于全寿命轴承与测试轴承数据分布的差异性,同工况下轴承的退化趋势也不尽相同,而不同工况下的轴承退化趋势也存在着一定的相似性,很难直观确定与测试轴承退化轨迹相似的全寿命轴承。因此有必要对各个

轴承的退化轨迹进行相似匹配,以具有相似退化轨迹的全寿命轴承为参考,为测试轴承设置合理的失效阈值。

4.3 基于退化轨迹的相似匹配的阈值设置

由于轴承的个体差异性和工况环境影响的不确定性,同工况下的轴承退化轨迹存在着明显的差异性,而不同工况的轴承也可具有相似的退化趋势。采用DTW算法对测试轴承与全寿命轴承的退化轨迹进行匹配分析,根据式(6)计算得到的轨迹匹配距离结果如表1所示。由表1可见,与全寿命轴承B1_1退化轨迹DTW距离最短的除了同工况下的B1_3、B1_7,还有异工况下的B3_3。同样,与全寿命轴承B1_2和轴承B3_1也分别存在异工况的测试轴承与其轨迹相匹配。

具有相似退化轨迹的轴承其失效阈值应具有一致性,采用式(12)的FOTP-GM(1,1)模型对全寿命轴承的DI曲线进行拟合,根据式(13)得到各个全寿命轴承的参考失效阈值,结合表1可整理得到每个测试轴承失效阈值设置如表2所示。

表1 退化轨迹间的DTW距离

测试轴承	全寿命轴承					
	B1_1	B1_2	B2_1	B2_2	B3_1	B3_2
B1_3	0.76	106	57.3	26.6	40.2	7.85
B1_4	261	0.59	4.98	0.88	0.57	216
B1_5	365	0.75	10.1	5.38	1.99	322
B1_6	321	4.79	8.73	10.8	7.91	250
B1_7	0.44	3.06	7.4	0.45	0.46	0.83
B2_3	14	45.2	14	10.6	13.3	14.1
B2_4	0.35	2.08	7.8	0.26	0.32	0.84
B2_5	166	3.05	4.71	0.7	0.77	123
B2_6	425	0.65	17.4	2.7	0.95	386
B2_7	255	0.63	5.16	1.71	0.49	210
B3_3	0.75	8.95	20.9	2.5	4.6	11.6

表2 各测试轴承失效阈值设置

序号	匹配轴承	测试轴承	失效阈值
1	B1_1	B1_3、B1_7、B3_3	1.755
2	B1_2	B1_5、B1_6、B2_6	0.880
3	B2_2	B2_3、B2_4、B2_5	1.300
4	B3_1	B1_4、B2_7	0.930

4.4 寿命预测

在测试轴承DI曲线与设定阈值的基础上,采用FOTP-GM(1,1)进行测试轴承的剩余寿命预测,根据预测的DI值平均相对误差对测试轴承各阶预测模型的性能进行量化评价,得到所有测试轴承的最佳模型阶数为4阶。轴承1_3、2_7的剩余寿命预测结果如图4所示。由图4可见,无论历史监测数据充足与否,FOTP-GM(1,1)模型都可以较准确地获得其剩余寿命。采用文献[22]提出的评价指标对所有测试轴

承的预测结果进行评分,有

$$E_i = (\text{actRUL}_i - \text{RUL}_i)/\text{actRUL}_i. \quad (13)$$

$$A_i = \begin{cases} \exp(-\ln(0.5)(E_i/5)), & E_i \leq 0; \\ \exp(+\ln(0.5)(E_i/20)), & E_i > 0. \end{cases} \quad (14)$$

$$\text{score} = \sum_{i=1}^{11} A_i / 11. \quad (15)$$

其中:actRUL_i、RUL_i、E_i和A_i分别为第i个测试数据的实际寿命、预测寿命、误差率和分数。将得分与振动频率特征异常检测法^[23]、WP-EMD + SOM^[22]、Multiple-features + RNN^[24]方法进行比较,结果如表3所示。

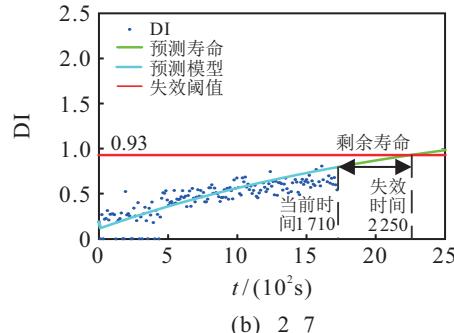
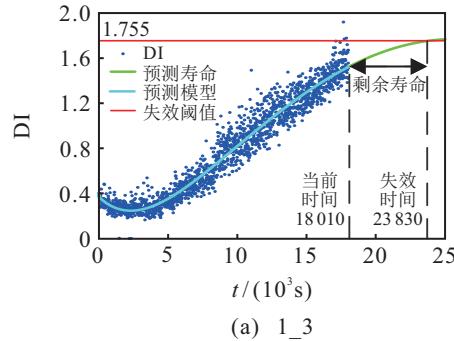


图4 轴承寿命预测图

表3 各算法得分比较

测试轴承	当前时间/s	实际寿命/s	预测寿命/s	误差率er/%			本文
				文献[22]	文献[23]	文献[24]	
B1_3	18010	5730	5820	37	-1.04	43.28	-1.57
B1_4	11380	339	350	80	-20.94	67.55	-3.24
B1_5	23010	1610	1200	9	-278.26	-22.98	25.47
B1_6	23010	1460	2040	-5	19.18	21.23	-39.73
B1_7	15010	7570	6590	-2	-7.13	17.83	12.95
B2_3	12010	7530	1610	64	10.49	37.84	78.62
B2_4	6110	1390	1250	10	51.8	-19.42	10.07
B2_5	20010	3090	3410	-440	28.8	54.37	-10.36
B2_6	5710	1290	1070	49	-20.93	-13.95	17.05
B2_7	1710	580	540	-317	44.83	-55.17	6.9
B3_3	3510	820	530	90	-3.66	3.66	35.37
score				0.31	0.36	0.26	0.47
SD of er				173.28	90.29	32.48	29.69

由表3可见,本文的score得分和预测误差率的标准差均优于文献[22-24],表明本文方法对于轴承寿命的预测具有更好的稳定性与鲁棒性。

5 结 论

本文提出了基于CAE的轴承性能退化特征提取方法,结合SOM构建了轴承运行状态DI,避免了信号特征提取、筛选及融合的人工繁琐步骤。该方法以目标轴承自监测数据为驱动进行深度模型建立,充分考虑了全寿命轴承与测试轴承之间的差异性与独立性。以正常状态下特征数据为基准建立DI曲线,不受测试轴承退化数据不足的影响。提出了基于DTW的轴承退化轨迹的相似匹配方法,并以全寿命周期的轴承失效阈值作为参考对同类退化轨迹的测试轴承失效阈值进行统一设置,避免了失效阈值的人为主观设置的盲目性问题。采用FOTP-GM(1,1)模型作为轴承剩余寿命的预测模型,克服了历史性衰退数据和先验知识不足的问题,在新的监测数据可用时能够自适应地更新性能退化轨迹。

本文方法与现有方法的实验结果对比表明,本文方法可以有效地提高预测的精度并降低预测的不确定性,具有较好的工程实践价值。

参 考 文 献(References)

- [1] 申中杰,陈雪峰,何正嘉,等. 基于相对特征和多变量支持向量机的滚动轴承剩余寿命预测[J]. 机械工程学报, 2013, 49(2): 183-189.
(Shen Z J, Chen X F, He Z J, et al. Remaining life predictions of rolling bearing based on relative features and multivariable support vector machine[J]. Journal of Mechanical Engineering, 2013, 49(2): 183-189.)
- [2] Ben A J, Fnaiech N, Saidi L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals[J]. Applied Acoustics, 2015, 89(3): 16-27.
- [3] 何群,李磊,江国乾,等. 基于PCA和多变量极限学习机的轴承剩余寿命预测[J]. 中国机械工程, 2014, 25(7): 984-989.
(He Q, Li L, Jiang G Q, et al. Residual life predictions for bearings based on PCA and MELM[J]. China Mechanical Engineering, 2014, 25(7): 984-989.)
- [4] 王奉涛,陈旭涛,柳晨曦,等. 基于KPCA和WPHM的滚动轴承可靠性评估与寿命预测[J]. 振动、测试与诊断, 2017, 37(3): 476-483.
(Wang F T, Chen X T, Liu C X, et al. Rolling bearing assessment and life prediction based on KPCA and WPHM[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(3): 476-483.)
- [5] Deutsch J, He D. Using deep learning based approaches for bearing remaining useful life prediction[C]. Annual Conference of the Prognostics and Health Management Society. Piscataway: IEEE, 2016: 292-298.
- [6] Ren L, Cui J, Sun Y Q, et al. Multi-bearing remaining useful life collaborative prediction: A deep learning approach[J]. Measurement, 2017, 43: 248-256.
- [7] Babu G S, Zhao P, Li X L. Deep convolutional neural network based regression approach for estimation of remaining useful life[C]. International Conference on Database Systems for Advanced Applications. Dallas, 2016: 214-228.
- [8] Guo L, Xing S B, Li N P, et al. Deep convolution feature learning for health indicator construction of bearings[C]. Prognostics and System Health Management Conference. Harbin: IEEE, 2017: 318-323.
- [9] Ren L, Sun Y Q, Cui J, et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks[J]. Journal of Manufacturing Systems, 2018, 48: 71-77.
- [10] Guo L, Li N P, Jia F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98-109.
- [11] Malhotra P, Vishnu T V, Ramakrishnan A, et al. Multi-sensor prognostics using an unsupervised health index based on LSTM encoder-decoder[J]. 2016, arXiv: 1608.06514.
- [12] 陈佳鲜,毛文涛,刘京,等. 基于深度时序特征迁移的轴承剩余寿命预测方法[J]. 控制与决策, 2021, 36(7): 1699-1706.
(Chen J X, Mao W T, Liu J, et al. Remaining useful life prediction of bearing based on deep temporal feature transfer[J]. Control and Decision, 2021, 36(7): 1699-1706.)
- [13] 何建樑. 基于深度特征表示的轴承剩余寿命迁移预测方法研究[D]. 新乡: 河南师范大学, 2019.
(He J L. Research on transfer prediction method of rolling bearings remaining useful life based on deep feature representation[D]. Xinxiang: Henan Normal University, 2019.)
- [14] Lei Yaguo, Li Naipeng, Gontarz Szymon, et al. A model-based method for remaining useful life prediction of machinery[J]. IEEE Transactions on Reliability, 2016, 65(3): 1314-1325.
- [15] Mao W T, He J L, Zuo M J. Predicting remaining useful life of rolling bearings based on deep feature representation and transfer learning[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1594-1608.

- [16] 康守强, 周月, 王玉静, 等. 基于改进 SAE 和双向 LSTM 的滚动轴承 RUL 预测方法 [J]. 自动化学报, DOI: 10.16383/j.aas.c190796.
(Kang S Q, Zhou Y, Wang Y J, et al. Rolling bearing rul prediction method based on improved SAE and bidirectional LSTM[J]. Acta Automatica Sinica, DOI: 10.16383/j.aas.c190796.)
- [17] 温杰彬, 杨文忠, 马国祥, 等. 基于 Apex 帧光流和卷积自编码器的微表情识别 [J]. 计算机工程与应用, 2021, 57(4): 127-133.
(Wen J B, Yang W Z, Ma G X, et al. Micro-expression recognition based on apex frame optical flow and convolutional autoencoder[J]. Computer Engineering and Applications, 2021, 57(4): 127-133.)
- [18] 张全德, 陈果, 林桐, 等. 基于自组织神经网络的滚动轴承状态评估方法 [J]. 中国机械工程, 2017, 28(5): 550-558.
(Zhang Q D, Chen G, Lin T, et al. Condition assessment for rolling bearings based on SOM[J]. China Mechanical Engineering, 2017, 28(5): 550-558.)
- [19] 李正欣, 郭建胜, 王瑛, 等. DTW 距离的过滤搜索方法 [J]. 控制与决策, 2018, 33(7): 1277-1281.
(Li Z X, Guo J S, Wang Y, et al. Filtering search method for DTW distance[J]. Control and Decision, 2018, 33(7): 1277-1281.)
- [20] 李守军. 基于模糊集理论的灰色预测模型及其应用 [D]. 徐州: 中国矿业大学, 2018.
(Li S J. Grey prediction model based on fuzzy set theory and its application[D]. Xuzhou: China University of Mining and Technology, 2018.)
- [21] Patrick N, Rafael G, Medjaher K, et al. PRONOSTIA: An experimental platform for bearings accelerated life test[C]. Proceedings of IEEE International Conference on Prognostics and Health Management. Denver: IEEE, 2012: 1-8.
- [22] Hong S, Zhou Z, Zio E, et al. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method[J]. Digital Signal Processing, 2014, 27: 159-166.
- [23] Sutrisno E, Oh H, Vasan A S S, et al. Estimation of remaining useful life of ball bearings using data driven methodologies[J]. IEEE Conference on Prognostics and Health Management, 2012: 1-7.
- [24] Guo L, Li N, Jia F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98-109.

作者简介

刘小峰(1980—), 女, 教授, 博士生导师, 从事工程信号处理、设备监测与故障诊断、智能测试与仪器等研究, E-mail: liuxfeng0080@126.com;

冯伟(1996—), 男, 硕士生, 从事机械设备故障诊断与寿命预测、非平稳信号处理的研究, E-mail: 1026761163@qq.com;

柏林(1972—), 男, 教授, 博士, 从事工程信号处理、设备故障诊断等研究, E-mail: bolin0001@aliyun.com.

(责任编辑: 郑晓蕾)

下期要目

- | | |
|---|--------|
| 基于深度学习的行人轨迹预测方法综述 | 孔 珂, 等 |
| 城市低空环境中多旋翼无人机在线航线规划方法 | 吴 宇, 等 |
| 基于 $\pm 3\sigma$ 正态概率区间分族遗传蚁群算法的移动机器人路径规划 | 包 汉, 等 |
| 具有重组学习和混合变异的动态多种群粒子群优化算法 | 唐可心, 等 |
| 一种基于多层语义特征的图像理解方法 | 莫宏伟, 等 |
| 考虑Showrooms效应的供应链定价与渠道模式策略 | 张雪梅, 等 |
| 基于一致性算法多模式搅拌器微波加热系统温度均匀性优化 | 杨 彪, 等 |
| 基于多种群分解预测的动态多目标引力搜索算法 | 刁鹏飞, 等 |
| 自适应直觉模糊相异直方图裁剪的图像增强算法 | 兰 蓉, 等 |
| 面向工业软测量应用的定制化生成对抗数据填补模型 | 姚邹静, 等 |
| 基于生成对抗网络的大规模路网交通流预测算法 | 代 亮, 等 |